

Control preventivo de sigatoka negra en cultivo banano apoyado en redes convolucionales.

Carlos Jorge Pallares Urieles
Departamento de Ingeniería de
Sistemas y Computación
Universidad del Norte
Barranquilla, Colombia
urielec@uninorte.edu.co

Keneth Stive Ortega Lallemand
Departamento de Ingeniería de
Sistemas y Computación
Universidad del Norte
Barranquilla, Colombia
klallemand@uninorte.edu.co

Fernando David Visbal Piedrahita
Departamento de Ingeniería de
Sistemas y Computación
Universidad del Norte
Barranquilla, Colombia
fpiedrahita@uninorte.edu.co

Profesor asesor de proyecto
Ph.D. Eduardo Zurek Varela
Profesor Asistente
Departamento de Ingeniería de
Sistemas y Computación
Universidad del Norte
Barranquilla, Colombia
ezurek@uninorte.edu.co

Resumen- Este trabajo se enfoca en resolver el problema de clasificación y detección de la enfermedad de la Sigatoka negra en plantas de banano, en términos de mejorar el proceso de detección utilizado en Colombia y reducir costos para el proceso de control de la enfermedad, basado en el uso de redes neuronales con el Arquitectura VGG19.

Palabras Clave: Machine Learning, Fouré, segmentación, redes neuronales convolucionales, Sigatoka Negra, enfermedad, foliar, preventivo, fitosanitario reducción de costos, agricultura de precisión.

I. INTRODUCCIÓN

El banano ha sido un fruto que ha lo largo de la historia ha tenido una gran influencia, no sólo en término mercantil y económico, sino que además ha repercutido en el ámbito social y político. Actualmente es uno de los productos agrícolas más vendidos y necesarios en el mundo, y su cuidado es una de las cosas que se tienen más en cuenta al cultivarlo. Sin embargo, como el ambiente es muy cambiante hay factores externos que deterioran la calidad y la producción de este fruto, como lo son enfermedades producidas por bacterias u hongos. En la costa caribe colombiana debido a sus condiciones únicas de temperatura,

humedad y luz solar las plantaciones de banano se ven afectadas por varias enfermedades tropicales de cultivo, siendo la más destructiva de todas, y por desgracia la más frecuente la Sigatoka Negra coloquialmente conocida como ‘Raya Negra’.



Figura 1. Cultivo destruido por la Sigatoka negra, nótese los racimos de banano con tamaño reducido [8].

La Sigatoka Negra, como ya se mencionó antes, es una enfermedad foliar provocada por el hongo *Mycosphaerella*

Fijiensis Morelet [4], en el cual la planta afectada por este hongo sufre de un deterioro rápido del tejido foliar, como consecuencia de esto se afecta la fotosíntesis de la planta y por ende su crecimiento y producción. La propagación del hongo también es una de las razones por las cuales es muy destructiva la enfermedad de la Sigatoka Negra, y puede presentarse por factores como:

- Precipitación
- Humedad relativa
- Brillo solar
- Temperatura

[10]

Además de que la alta densidad de siembra, fertilización inadecuada o impuntual, falta de canales de drenaje, retraso en labores culturales como deshoje, cirugías, nutrición y manejo de malezas hacen que el manejo de la enfermedad sea más difícil de controlar.



Figura 2. Operario realizando deshoje preventivo en lotes de la Finca Doña Flor, Zona Bananera del Magdalena - Banesco. Fuente propia.

Este hongo se puede reproducir sexualmente en las lesiones maduras denominadas peritecios o pseudotecios, en el cual se encuentran las ascosporas, que al final se liberan al ambiente en periodos de alta humedad, donde el aire acilita su transporte hacia otra planta; y de manera asexual donde se presenta en lesiones jóvenes de la enfermedad, en el cual los conidios aparecen en los conidióforos que pasan por los estomas y que al final son dispersados por el salpique de la lluvia.

Gracias a todos estos factores las plantaciones pierden mucho su calidad al punto de que las plantas logran perder el 50% del peso del racimo y puede causar hasta un 100% de la pérdida de la producción debido a que la calidad del fruto se

pierde (longitud y grosor), según los expertos Mauricio Guzmán Quesada y Roxana Paladines García [5]



Figura 3. Hoja de banano afectada por la Sigatoka Negra en la Finca Doña Flor, Zona Bananera del Magdalena - Banesco. Fuente propia.

Por esta razón es difícil de erradicar el hongo, así que se han desarrollado técnicas para manejar niveles bajos de propagación de la enfermedad como el uso de fungicidas o aceite agrícola. Sin embargo, para la utilización de estos métodos hay que saber que plantas han sido infectadas para poder usarlos sin tener que usarlos en toda la plantación, ya que eso conlleva a un gasto económico más grande para poder encargarse de la enfermedad. El otro problema es que esta enfermedad es difícil de detectar por el ojo humano en sus etapas más tempranas y tener que clasificarlas es un proceso tedioso, pero gracias al avance de la tecnología se han podido usar métodos de detección más rápidos y eficaces usando Machine Learning

a. Definición del problema

La sigatoka negra ha sido uno de los principales problemas fitosanitarios del banano que más gastos genera en plantaciones del mismo en el Magdalena, los gastos cubren el saneamiento general de las etapas de la sigatoka negra con fumigación aérea y/o por bomba con un operario terrestre. Dichas técnicas se hacen de manera periódica, es decir no se tiene un control preventivo que pueda hacer variar estos periodos o anularlos por un tiempo caso tal el hongo no esté presente.

Realizar un control preventivo es una tarea exhaustiva que debe realizarse revisando planta por planta y hoja por hoja, y al ser una tarea tan monótona y repetitiva la automatización es fundamental. Por esto se plantea una técnica de captura de imágenes de alta resolución del cultivo (hojas) y luego procesarlas para determinar el porcentaje de incidencia de la sigatoka negra en un sector con el fin de

realizar las acciones preventivas y/o correctivas pertinentes, reduciendo los costos fitosanitarios, principalmente representados por el coste por hectárea de vuelo del vehículo aéreo usado para fumigación (avioneta), las horas de trabajo del personal de fumigación terrestre, valor del plaguicida y reducir el error humano.

b. Mapa del problema

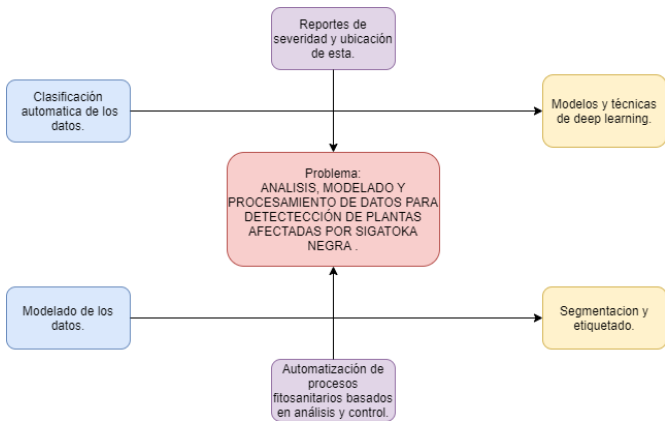



Figura 4. Mapa del Problema. Fuente propia.

c. Justificación

La siguiente investigación presentará una metodología para detección de sigatoka negra en plantaciones de banano que enmarcamos en el concepto de agricultura de precisión, basada en aprendizaje supervisado lo que nos permitirá romper el estigma que esta es una tecnología que solo es desarrollada e investigada por terceros fuera de nuestro país, a su vez ser un pivote para nuevos marcos de trabajo y operabilidad.

Dar a conocer la utilidad de estas metodologías es necesario para olvidar prejuicios actuales respecto a la implementación de TIC's y herramientas de inteligencia artificial como las siguientes que fueron obtenidas de la pregunta “¿por qué motivos no cuenta con un área, dependencia o persona encargada de los temas de TIC?” :

Gráfico 3. Respuestas de las empresas a la pregunta: ¿por qué motivos no cuenta con un área, dependencia o persona encargada de los temas TIC?



Fuente: elaboración propia con datos de la Primera Gran Encuesta TIC 2017-Ministerio de Tecnologías de la Información y las Comunicaciones, 2017.

Figura 5. Gráfico de muestras del porqué no se tienen un encargado de las TIC en empresas [9].

Los siguientes objetivos expuestos en el documento Conpes 3975 del 2019 .pág 3 expresan la justificación general de este trabajo:

- Crear las condiciones habilitantes para la innovación digital, privada y pública como medio para aumentar la generación de valor económico y social mediante nuevos procesos y productos
- Desarrollar condiciones habilitantes para preparar a Colombia para los cambios económicos y sociales que conlleva la inteligencia artificial (IA), reconociendo esta tecnología como un acelerador clave de la transformación digital.

Las justificaciones específicas están basadas en producción, control preventivo, ahorro de costos y centralización de actividades a futuro, siendo nuestra solución más adelante planteada un abanico de actividades como:

- Reducción de costos fitosanitarios al minimizar las zonas de aspersión de fungicidas.
- Centralización de los cuidados y costos en sectores específicos.
- Automatización del seguimiento de zonas afectadas y evolución de estas.
- Prevención de dispersión de la sigatoka a otros sectores.

La implementación automatizada de la detección y seguimiento de sigatoka negra es necesario ya que su evolución puede variar drásticamente solamente con el incremento de la humedad, por lo cual un operador terrestre fallaría al ir diferentes días y al recorrer hectáreas de banano.

Estudios de detección de diferentes enfermedades en el banano incluyendo la sigatoka negra han sido abordados desde un punto químico desarrollando estudios en fungicidas en el sector del Urabá [1], cómo computacional, planteado por Patil y Chaudari [7] en el año 2020 usando clustering K-means con una precisión del 85% para identificación de diferentes patologías igual que Gomez, Vergara y Ruíz en [3] usando redes convolucionales pre entrenadas y Aruraj, Alex y Subathra en [6] usando SVM. Nuestra técnica de detección está enfocada solamente a la sigatoka negra, por lo cual evidenciamos resultados con precisión mayor al 90% en detección de la presencia o no del hongo.

II.METODOLOGÍA

En temas de inversión y de producción, la sigatoka ha sido un foco de mucha atención, solo para el 2014 el ministerio de agricultura invirtió 12.500 millones de pesos para asistencia técnica y capacitaciones en control de sigatoka y adicional, diferentes entidades bananeras invirtieron 8.000 millones de pesos [14]. Dicha inversión fue destinada a las 47.000 hectáreas de banano distribuidas entre la Guajira, Magdalena y el Urabá Antioqueño [15].

Ninguna de las asistencias ofrecidas en el plan de los aproximadamente 20.000 millones de pesos incluye modernización de infraestructura, equipos de detección ni implementaciones apoyadas en TIC's para la detección de sigatoka negra. El objetivo futuro de este proyecto es la implementación en tiempo real y mejorada de nuestro prototipo que incluso aterriza y es aplicado sobre una y que inclusive consideramos una herramienta de utilidad basándonos en los resultados arrojados por el mismo para la toma de decisiones.

d. Objetivos General

Diseñar e implementar una aplicación basada en redes neuronales convolucionales para detectar, clasificar y analizar plantas de banano infectadas con Sigatoka Negra con el fin de mejorar procesos de control fitosanitarios.

e. Objetivos Específicos

- Elaborar una revisión sistemática de la literatura asociada con las aplicaciones de las redes neuronales convolucionales en procesos de control fitosanitario para el banano.
- Elaborar la arquitectura lógica de la solución para detectar, clasificar y analizar plantas de banano infectadas con Sigatoka Negra aplicando técnicas de deep learning.
- Implementar y evaluar un prototipo que de solución a la detección, clasificación y análisis de plantas de banano aplicando técnicas de deep learning.
- Formular una arquitectura lógica para un despliegue futuro en campo de análisis y control fitosanitario.

A continuación se describe el modelo base, técnicas y detalles que permitieron el desarrollo efectivo de la solución expresada en nuestro prototipo:

a. Modelo de la solución:

El siguiente esquema fue basado en [2] página 3 y [12] página 2 :

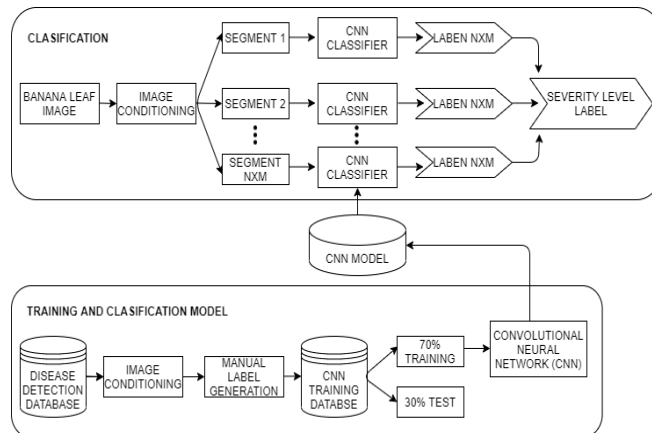


Figura 6. Esquema de entrenamiento y clasificación del modelo. Fuente propia.

Desarrollamos dos etapas: **entrenamiento-validación de modelos y clasificación**. Abordaremos detalle en el orden mencionado

Entrenamiento y modelo de clasificación:

Base de datos de hojas infectadas: el conjunto de datos consta de imágenes de hojas de banano en escala RGB

Condicionamiento de imágenes: se hará una reducción de resolución para cada imagen, su tamaño original 4608 x 3456 y es reducida a 500 x 375 píxeles, reduciéndose un 89.13% a su tamaño original, luego será segmentada en cuadrados de 50 x 50 píxeles (utilizando la operación matemática módulo para su alto y largo evitamos zonas desiguales o errores de código) obteniendo un total de 70 segmentos por imagen.

Generación manual de etiquetas: los segmentos son etiquetados de forma manual, sanos y enfermos y son guardados en un documento .csv de la siguiente forma:

	A	B
1	sano	enfermo
2	0	1
3	0	1
4	0	1
5	0	1

Figura 7. Etiquetado de los segmentos. Fuente propia.

Base de datos para entrenamiento: acá dividimos el conjunto de datos anteriormente condicionados, 70% de estos para entrenamiento de nuestra red neuronal convolucional y 30% para pruebas y validación apoyándonos en matrices de confusión y curvas de ROC.

Clasificación:

Condicionamiento de imágenes: el input para nuestro modelo es una imagen que se divide en segmentos de 50x50 píxeles que son el input de nuestra red neuronal. La segmentación es realizada usando funciones de la librería OpenCV

Clasificador CNN: la red neuronal es una pre entrenada, el modelo VGG19, aplicada a cada segmento, clasificándolos en infectado o sano (Label) .

Comenzaremos con pesos (filtros) fijos para cada capa de la parte convolucional, nuestra elección de pesos fue Imagenet. Los pesos de las capas de clasificación son los únicos que cambiarán por el entrenamiento, ajustándose lo más posible a los resultados deseados (entrenamiento supervisado), la salida será un vector de dos posiciones de la forma [x_1,x_2].

x_1 representa la probabilidad de que el segmento ingresado sea sano y x_2 de que no lo sea.

La arquitectura del modelo de deep learning utilizada (CNN) es la siguiente:




Figura 8. Arquitectura VGG-19 [16]

Adaptando la arquitectura anterior a nuestra solución, la entrada de nuestra red es un tensor de la forma 50x50x3. 50x50 siendo la cantidad de píxeles por segmento, y 3, los 3 colores de la escala RGB de cada píxel.

El entrenamiento de la red se realizó bajo los siguientes hiperparametros:

- epochs = 10
- batch_size = 10
- loss = mean_squared_error
- optimizer = sgd
- metrics = acc

Para las últimas capas de la red, las capas de clasificación, usamos la función de activación Relu, y Sigmoidal para la capa de salida.

Conteo de etiquetas: se cuentan el número de etiquetas infectadas.

Nivel de severidad: a partir de Label count se genera un nivel de infección en la hoja que es el equivalente a un porcentaje de infección sobre el área foliar de esta siendo la última etapa del modelo. Esto es basado en el método Stover modificado por Ghaul (1989) para definición de severidad explicado en las siguientes imágenes [13]:




Figura 9. Grado de severidad basado en el método Stover modificado por Ghauri [13].

“Para determinar el área foliar afectada (en cada hoja) debe estimarse visualmente el área total afectada y calcular el porcentaje de la hoja cubierta por los síntomas (se usa el patrón que divide la hoja en proporciones porcentuales)”[13].

No existe una estrategia de división y la mostrada en la primera imagen no es acertada ya que la sigatoka negra puede aparecer en diferentes sectores de la hoja, y no de su punta hacia el tallo de la planta. La división que tomamos nosotros fue la expuesta de 70 segmentos a 50 x 50 píxeles cada uno y a partir de esta calculamos un porcentaje de infección igual a:

$$Severity\ level = \left(\frac{Label\ count}{70} \right) * 100$$

b. Información detallada de datos y modelo:

Datos: Se tomaron 344 fotos en el sector de la Zona Bananera del Magdalena, Finca Doña Flor - empresa Banesco, entre sanas y enfermas, de las cuales solo se usaron para entrenamiento y validación las siguiente cantidad:

- 10 hojas sanas (700 segmentos)
- 10 hojas infectadas con sigatoka negra (700 segmentos)

La recolección de fotos fue realizada con una cámara Nikon Coolpix bajo la siguientes condiciones:

- Espacio de color: RGB
- Longitud focal: 4 mm
- Canal alfa: No
- Ojos rojos: No
- Modalidad de medición: Patrón
- Número f: f/3
- Programa de exposición: Normal
- Tiempo de exposición: 1/500
- Resolución máxima: 16 MP
- Resolución fijada: 4608 x 3456 pixeles

El procesamiento de los datos y entrenamiento del modelo fue realizado en un portátil con las siguientes características:

- Modelo: MacBook Pro (13-inch, Mid 2012)
- Procesador: 2.5GHz Intel Core i5
- Memoria: 4 GB 1600 MHz DDR3
- Sistema operativo: macOS Mojave
- Disco duro: SSD Kingston 120 GB

III.RESULTADOS

a. Precisión del modelo VGG19:

Los resultados obtenidos en tema de precisión y perdida para entrenamiento y validación del modelo fueron respectivamente los siguientes:




Figura 10. Gráfica de posición de entrenamiento y validación. Fuente propia.




Figura 11. Gráfica de pérdida de entrenamiento y validación. Fuente propia.

Independiente de los cambios en los valores de la pérdida y precisión para la validación entre los epochs 7 y 9, el modelo muestra un buen desempeño y los cambios entre estos epochs es menor a 0.05, por lo cual decidimos seguir trabajando con este modelo.

b. Verdaderos y falsos positivos y curva de ROC:

Los datos de validación contienen 145 datos infectados y 271 sanos de los cuales 5 y 12, respectivamente, fueron mal clasificados. La siguiente matriz de confusión expresa gráficamente lo anterior:




Figura 12. Matriz de confusión Sanos/Infectados. Fuente propia.

La tasa de verdaderos positivos con respecto a lo predicho tanto para sanos como enfermos es mayor al 90% a diferencia de los falsos positivos que están por debajo del 10% la cantidad de datos sanos e infectados.

La siguiente curva de ROC apoya la precisión y tasa de verdaderos y falsos positivos:




Figura 13. Gráfica Curva de ROC. Fuente propia.

El área bajo la curva comprendida entre la línea punteada y la continua es 0.961, aproximadamente 1, lo que indica que la clasificación del etiquetado fue en su mayoría correcta.

c. Ejecución del prototipo:

Los resultados arrojado será un informe contenido en una carpeta llamada “result” que consta con los siguientes elementos:




Figura 14. Resultados de la predicción. Fuente propia.

result/image: folder con imágenes procesadas y sus respectivas zonas infectadas:

DSCN0041.JPG




Figura 15. Hoja de banana con puntos de la enfermedad de la Sigatoka Negra detectados. Fuente propia.

Los puntos rojos son los centros de los segmentos afectados, los segmentos sanos no son marcados.

result/resultado.xlsx: documento Excel con 4 columnas, Latitud, y Longitud donde se tomó la foto, Magnitud(%) que corresponde al porcentaje infectado de la imagen procesada, Imagen siendo el nombre de la imagen original. El archivo se .xlsx es el siguiente:

	Latitud	Longitud	Magnitud(%)	Imagen
0	10.85066	-74.1422	0	DSCN0385.JPG
1	10.85079	-74.14205	17.14285714	DSCN0042.JPG
2	10.85054	-74.14211	4.285714286	DSCN0081.JPG
3	10.85074	-74.14184	57.14285714	DSCN0041.JPG

Figura 16. Resultados de la predicción en CSV. Fuente propia.

/result/mapa.html: es un archivo generado por la API de GoogleMaps conectada a nuestro proyecto en el cual se muestran las zonas evaluadas. La intensidad del color verde representa la intensidad de la infección, entre más tenue, menos infección hay presente:



Figura 17. Mapa con localizaciones de las plantas enfermas

La siguiente imagen ilustra el flujo de datos desde la entrada de datos hasta la salida de informes relacionados con la severidad de la planta:




Figura 18. Flujo de datos del prototipo. Fuente propia.

IV. TRABAJOS FUTUROS

A partir del desarrollo comprendido desde el inicio de nuestro proyecto encontramos posibilidades de crecimiento a futuro, principalmente el despliegue en campo de un aplicativo como herramienta funcional para el soporte de toma de decisiones respecto al control fitosanitario. A continuación se presenta un prototipo arquitectura para el posible despliegue:

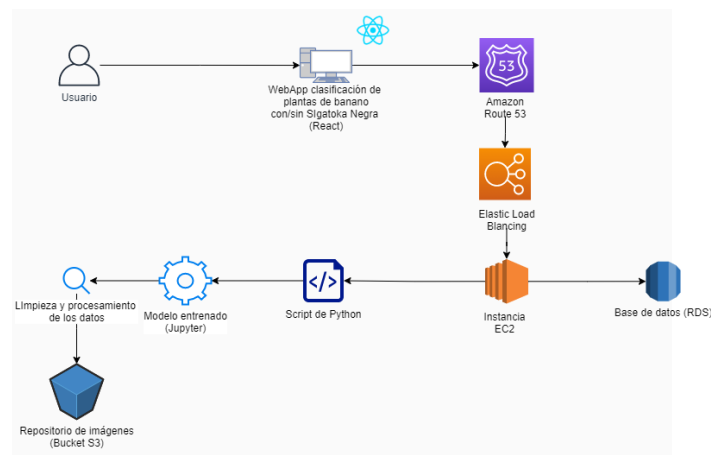


Figura 19. Arquitectura del aplicativo. Fuente propia

a. Explicación de la arquitectura

La arquitectura del proyecto se divide en dos partes fundamentales. Por un lado tenemos el modelo entrenado para la clasificación pertinente, y por otro lado tenemos la aplicación web.

Usando la aplicación web se obtienen las imágenes que se requieran clasificar como planta enferma o no enferma, donde esta información se guarda en la nube con una instancia de RDS de Amazon. Los datos son obtenidos por el Backend desarrollado en FastAPI y mostrados por el Frontend, que está constituido con React, usando Bulma como biblioteca de estilos y usando GraphQL como lenguaje de consultas que permita la conexión entre dicho frontend con el backend.

Para el proceso de clasificación de la imagen se usa una red neuronal pre-entrenada VGG19, en el cual se hace un proceso de segmentación, limpieza y clasificación de los datos mediante scripts de Python, las cuales usan las librerías de OpenCV, Numpy, Pandas y Tensorflow, y el uso de hojas de cálculo de Excel, que al final permite determinar el estado de la planta y el porcentaje de infección que lleva. Al final se devuelve esta información al Backend de la aplicación para que el resultado pueda ser visualizado en el Frontend.

b. Modelo de datos

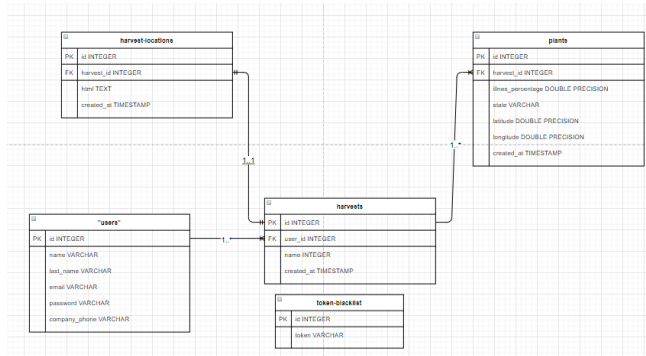


Figura 20. Diagrama de clases del prototipo. Fuente propia.

Como parte del planteamiento para una futura implementación creamos un prototipo básico del diagrama de clases como se ve en la Figura 17:

- **Users:** Los usuarios que suelen ser de alguna empresa, que tienen cultivos y sus porcentajes de severidad de la enfermedad.
- **Harvests:** Los cultivos de los propios usuarios. Tienen las plantas para evaluar su estado y el archivo HTML de su locación.
- **Plants:** Son las plantas de un determinado cultivo. En ellos se comprende su porcentaje de severidad de la enfermedad, su latitud y longitud (localización), y el estado que tiene determinado por la aplicación.
- **Harvest Locations:** Son los archivos en HTML de las localizaciones de las plantas en el cultivo, en el cual se puede visualizar usando la API de Google Maps.
- **Token Blacklist:** Son los tokens que se habían generado por la aplicación para las autorizaciones de las peticiones al servidor y se guardan para que no se utilicen más en las próximas autorizaciones.

V. CONCLUSIONES

Como se planeo en todo el documento anterior, se realizó el uso de una red neuronal convolucional pre-entrenada del tipo VGG19 con la cual, se realiza el reconocimiento de la infección de Sigatoka negra en plantas de banano, todo esto con la intención de crear una herramienta de fácil uso y gran escalabilidad a la hora de complementar y guiar procesos fitosanitarios más económicos, sostenibles y precisos, la implementación de la API de GoogleMaps facilita en análisis y aumenta la precisión en la toma de decisiones ya que muestra resultados más explícitos y comprensibles para el usuario interesado.

Para el modelo neuronal, se realizaron una serie de procedimientos con los cuales pudimos obtener una alta probabilidad de detección de plantas enfermas, sin embargo pudimos observar que en algunas hojas presentaban algunos fallos de detección, principalmente en hojas que son completamente sanas. A través de estos resultados pudimos determinar que para obtener resultados más precisos, y de esta manera aumentar la utilidad de la herramienta, hace falta cambiar algunos procesos, como lo es el la toma de imágenes en escalas multiespectrales para el entrenamiento del modelo utilizando drones este tipo de cámaras (sensores NDVI).

Para tener un contexto de estas cámaras, el NDVI o Normalized Difference Vegetation Index (en español Índice de Vegetación de Diferencia Normalizada) es un índice de vegetación que se utiliza para estimar la cantidad, calidad y desarrollo de un cultivo mediante la medición de ciertas bandas de espectro electromagnético que la vegetación emite [11]. Gracias a esto es posible determinar zonas muertas en las plantas infectadas, ya que el espectro que emiten estas zonas infectadas son diferentes a las zonas sanas, puesto que las plantas su color verde lo obtiene por la fotosíntesis y en este proceso interviene la luz del sol, ahora, si estas zonas están infectadas el espectro dará un resultado diferente por como se refleja la luz del sol en estas zonas.

El desarrollo de esta herramienta tuvo un fin agregado y es la extrapolación de la solución a otro tipo de cultivos como el café y combatir la presencia de roya, siendo el principal hongo que afecta a este cultivo. La roya presenta coloraciones parecidas a la sigatoka negra en hojas sanas de café. Para este caso se deben considerar otras especificaciones para la recolección de datos como:

- Fijar la posición promedio de la cámara con respecto a la planta que permita una lectura apropiada.
- El tipo de cámara.
- Condiciones lumínicas (horarios de recolección de datos)

A partir de lo comentado anteriormente, y debido al enfoque práctico de la herramienta, se planea complementar los medios de recolección de datos del sistema con diversos sensores en campo, como sensores de humedad, oxigenación de tierra. Además de conectarlo con sistemas de arquitectura de precisión de terceros por medio de una API abierta, que permita tanto aumentar la precisión de la herramienta disminuyendo falsos positivos, como aumentar la utilidad de los datos e integración con otras soluciones de software y/o hardware, con la intención de convertirse en una herramienta indispensable en la agricultura de precisión del hoy y el mañana.

VI. AGRADECIMIENTOS

Agradecimientos a :

Semillero de investigadores - Uninorte
Carlos Robles
Luz Adriana Mejia
Manuel Becerra
Nicolas Yaya

VII. REFERENCIAS

- [1] INTEGRACIÓN DE INDUCCIÓN DE RESISTENCIA CON BACTERIAS QUITINOLÍTICAS EN EL CONTROL DE LA SIGATOKA NEGRA (Mycosphaerella fijiensis Morelet Morelet Morelet) EN BANANO EN BANANO EN BANANO Catalina María Zuluaga Amaya, Luis Fernando Patiño Hoyos y Juan Carlos Collazos Villa , 2017
- [2] J. Amara, B. Bouaziz, and A. A. Algergawy, "Deep learning-based approach for banana leaf diseases classification," Lecture Notes in Informatics (LNI), 2017.
- [3] M. Gomez, A. Vergara, H. Ruiz et al., "AI-powered banana diseases and pest detection," Plant Methods, 2019.
- [4] "Sigatoka Negra," CropLife Latin America. <https://www.croplifela.org/es/plagas/listado-de-plagas/sigatoka-negra>
- [5] A Machine Learning Approach for Detection Plant Disease: Taking Orchid as Example (Li-Hua Li, Yu Sheng Chu, Jui-Yuan Chu, Shian-Hau Guo) - 2019
- [6] A. Aruraj, A. Alex, M. S. P. Subathra, N. J. Sairamya, S. T. George and S. E. V. Edwards, "Detection and Classification of Diseases of Banana Plant Using Local Binary Pattern and Support Vector Machine"
- [7] V. Chaudhari and M. Patil, "Banana leaf disease detection using K-means clustering and Feature extraction techniques" - 2020
- [8] "Necesita Vencer la Sigatoka Negra en el Cultivo de Banano? – Plantation Solutions." <http://www.plantationsolutions.com/es/answer/necesita-vencer-la-sigatoka-negra-en-el-cultivo-de-banano/>
- [9] Documento Conpes 3975 - POLÍTICA NACIONAL PARA LA TRANSFORMACIÓN DIGITAL E INTELIGENCIA ARTIFICIAL, 2019
- [10] Muñoz Ruiz, Carlos; Vargas Jarquín, Edgardo Manejo de Sigatoka negra (Mycosphaerella Fijiensis var. Difformis Morelet) en plátano cv. "Curarré" en San Carlos, Zona Norte, CUADRO 1. Tecnología en Marcha. Vol. 18-3, 2006
- [11] D. Alonso and D. Alonso, "NDVI: Qué es y cómo calcularlo con SAGA desde QGIS - MappingGIS",

MappingGIS, 2021. [Online]. Available: <https://mappinggis.com/2015/06/ndvi-que-es-y-como-calcularlo-con-saga-desde-qgis/>. [Accessed: 16- May- 2021]

[12] Cristian A. Escudero, Andrés F. Calvo, and Arley Bejarano, Black Sigatoka Classification Using Convolutional Neural Networks, *International Journal of Machine Learning and Computing*, Vol. 11, No. 4, July 2021

[13] Hector C., Joel Y., La Sigatoka Negra en el Ecuador - I Seminario Internacional Metodología para la Evaluación de Prueba de Eficacia para Plaguicidas en los principales cultivos del Ecuador, 2014

[14] “Con \$12.500 millones MinAgricultura impulsa competitividad de cultivos de banano | Finagro.”
<https://www.finagro.com.co/noticias/con-12500-millones-minagricultura-impulsa-competitividad-de-cultivos-de-banano>

[15] Finagro.com.co. 2018. *FICHA DE INTELIGENCIA BANANO*. [online] Disponible en:
https://www.finagro.com.co/sites/default/files/node/basic-page/files/ficha_banano_version_ii.pdf

[16] Silva González, A. and Paternain Dallo, D., 2020. *Estudio comparativo de modelos de clasificación automática de señales de tráfico*. [online] *Academica-e.unavarra.es*. Disponible en:
<https://academica-e.unavarra.es/xmlui/bitstream/handle/2454/37479/Memoria.pdf?sequence=1&isAllowed=y>